

Klasifikasi Sinyal EEG Untuk Mengenali Jenis Emosi Menggunakan Deep Learning

Pita Rosemari, Dian Palupi Rini, Winda Kurnia Sari*

Fakultas Ilmu Komputer, Magister Ilmu Komputer, Universitas Sriwijaya, Palembang, Indonesia

Email: ¹09012682226007@student.unsri.ac.id, ²dprini@unsri.ac.id, ^{3,*}windakurniasari@unsri.ac.id

Email Penulis Korespondensi: windakurniasari@unsri.ac.id

Submitted: 15/12/2023; Accepted: 28/12/2023; Published: 29/12/2023

Abstrak– Penelitian ini berfokus pada eksplorasi mendalam dan analisis tentang penerapan tiga jenis Deep Learning, yakni Convolutional Neural Networks (CNN), Bidirectional LSTM (Bi-LSTM) dan Deep Neural Network (DNN). Tiga model tersebut dilatih dengan parameter yang sama, terdiri dari tiga lapisan, menggunakan fungsi aktivasi relu, dan menerapkan 1 tingkat dropout. Dalam rangka membandingkan kinerja ketiganya, dilakukan percobaan dengan menggunakan tiga kelompok dataset untuk keperluan pelatihan dan evaluasi performa. Evaluasi tersebut mencakup metrik-metrik seperti akurasi, recall, F1-score, dan area di bawah kurva (AUC). Dataset yang digunakan adalah eeg emotion yang terdiri dari 2458 variabel unik. Dalam hal kinerja, Bi-LSTM berhasil mengungguli performa CNN dan DNN dalam tugas klasifikasi data emosi berdasarkan sinyal eeg. Di sisi lain, CNN dan DNN menunjukkan kelebihan dalam percepatan proses pelatihan dibandingkan Bi-LSTM. Meskipun akurasi kedua metode hampir serupa dalam semua pembagian data, namun dalam evaluasi kurva ROC, model Bi-LSTM mendemonstrasikan keunggulan dengan kurva yang lebih optimal dibandingkan CNN dan DNN.

Kata Kunci: Convolutional Neural Networks (CNN); Bidirectional LSTM (Bi-LSTM); Deep Neural Network (DNN); Sinyal EEG

Abstract–This research focuses on in-depth exploration and analysis of the application of three types of deep learning, namely Convolutional Neural Networks (CNN), Bidirectional LSTM (BI-LSTM) and Deep Neural Network (DNN). The three models are trained with the same parameters, consisting of three layers, using the Relu activation function, and applying 1 dropout level. In order to compare the performance of the three, experiments were carried out using three dataset groups for training and evaluation of performance. The evaluation includes metrics such as accuracy, recall, F1-Score, and areas under the curve (AUC). The dataset used is EEG Emotion which consists of 2458 unique variables. In terms of performance, BI-LSTM succeeded in outperformed the performance of CNN and DNN in the task of classification of emotional data based on EEG signals. On the other hand, CNN and DNN show excess in the acceleration of the training process compared to BI-LSTM. Although the accuracy of the two methods is almost similar in all data distribution, but in the evaluation of the ROC curve, the BI-LSTM model demonstrates superior with a more optimal curve than CNN and DNN.

Keywords: Convolutional Neural Networks (CNN); Bidirectional LSTM (Bi-LSTM); Deep Neural Network (DNN); Sinyal EEG

1. PENDAHULUAN

Donmez & Ozkurt dalam penelitiannya pada tahun 2019 menjelaskan otak merupakan salah satu organ utama tubuh manusia yang memiliki fungsi vital bagi kehidupan manusia [1]. Salah satu fungsi otak adalah mengatur emosi yang dirasakan oleh manusia. Mei & Xu dalam penelitiannya pada tahun 2017 mendeskripsikan bahwa emosi adalah gambaran utama mengenai mental dan psikologis manusia, penelitian dibutuhkan untuk mempelajari otak manusia dan pola operasi [2]. Sedangkan Huang dkk pada penelitiannya pada tahun 2017 mengungkapkan bahwa emosi juga merupakan cerminan dari persepsi terhadap berbagai hal yang dekat dengan kesehatan psikis dan mental tubuh manusia [3]. Zhang dkk dalam penelitiannya pada tahun 2020 menjelaskan emosi adalah keadaan mental atau proses manusia yang sangat kompleks, yang dapat mencerminkan persepsi dan sikap manusia serta memainkan peran penting dalam komunikasi antar manusia [4]. Sedangkan menurut Yang dkk dalam penelitiannya pada tahun 2017 mengungkapkan bahwa emosi juga merupakan manifestasi dari kesadaran dan perilaku manusia untuk mencerminkan niat dan perilaku yang akan dilakukan seseorang [5]. Sebagian besar penelitian berkonsentrasi pada bagaimana aktivitas otak berubah dengan respons terhadap keadaan emosi dan bagaimana mengklasifikasikannya secara akurat. Beberapa dari mereka berfokus pada pemisahan emosi negatif dan positif. Nalban dkk menjelaskan emosi juga merupakan manifestasi dari kesadaran dan perilaku manusia untuk mencerminkan niat dan perilaku yang akan dilakukan seseorang.[5].

Penelitian Donmez & Ozkurt pada tahun 2019 menggambarkan bahwa sebagian besar penelitian berkonsentrasi pada bagaimana aktivitas otak berubah dengan respons terhadap keadaan emosi dan bagaimana mengklasifikasikannya secara akurat. Beberapa dari mereka berfokus pada pemisahan emosi negatif dan positif [1]. Lasiman dan Lestari dalam penelitiannya pada tahun 2018 menggambarkan emosi merupakan bentuk ekspresi manusia terhadap sesuatu hal ataupun seseorang. Ekspresi emosi dalam sebuah percakapan berperan penting dalam memberikan penekanan pada informasi yang disampaikan menjadi lebih kuat daripada hanya dengan kata-kata saja [6].

Zhuang dkk dalam penelitiannya tahun 2019 menjelaskan bahwa dalam bidang medis, pengenalan emosi juga sangat penting. Bagi pasien, kualitas keadaan emosi akan berdampak besar pada proses perkembangan penyakit dan pengobatan yang sesuai sistem manajemen [7]. Meskipun penelitian medis saat ini tidak memiliki

bukti pasti untuk membuktikan hubungan antara keadaan emosi dan penyakit, keadaan emosi positif sebenarnya kondusif untuk pemulihan penyakit dan kesehatan fisik dan mental. Ketika pasien berada dikeadaan negatif dan tidak bekerja sama dengan pengobatan, penyembuhan penyakit biasanya sangat lambat, dan bahkan dapat menyebabkan memburuknya penyakit. Oleh karena itu, Nalbant dkk dalam penelitiannya pada tahun 2019 menjelaskan deteksi keadaan emosional relatif penting bagi pasien. Sebisa mungkin menempatkan pasien dalam keadaan emosional yang positif dapat mendorong perkembangan penyakit yang baik. Sementara itu, Nalbant dkk menekankan bahwa pengenalan emosi juga bermanfaat untuk pencegahan dan pengobatan depresi dan penyakit lainnya [8].

Pengenalan emosional dapat dibagi menjadi dua kategori Satu didasarkan pada pengenalan emosi sinyal non-fisiologis, juga dikenal sebagai faktor eksternal, sebagian besar penelitian didasarkan pada sinyal tersebut, termasuk ekspresi wajah, teks emosional, nada suara, dan gerakan tubuh. Pengenalan emosi berdasarkan sinyal non-fisiologis memberi orang perasaan yang lebih intuitif, melalui ekspresi wajah, nada suara dapat menjadi deskripsi emosi manusia yang lebih cepat. Namun, nada suara manusia, ekspresi wajah, gerakan fisik, dan sinyal eksternal lainnya sebagian besar tunduk pada indera kontrol dan pengaruh subjektif, oleh karena itu sinyal eksternal untuk pengenalan emosional ini dalam beberapa kasus akan menjadi tidak valid. Yang lainnya didasarkan pada fisiologis sinyal pengenalan emosional. Frekuensi pernapasan, denyut nadi frekuensi, impedansi kulit (SC), elektrokardiogram (EKG), electromyogram (EMG), dan EEG dapat digunakan sebagai fisiologis sinyal untuk mengidentifikasi emosi. Penelitian yang dilakukan oleh Yang dkk pada tahun 2018, Sinyal EEG sebagai sinyal neurofisiologis sentral, hubungan dengan emosional lebih dekat, mudah diperoleh, dan tunduk pada kontrol subyektif individu adalah pilihan yang baik untuk pengakuan emosional [5]. Sehingga Sinyal EEG digunakan dalam penelitian ini untuk melihat klasifikasi jenis emosi. Rani dalam penelitiannya pada tahun 2016 menjelaskan bahwa Tujuan dari klasifikasi ini untuk mencari suatu himpunan model (fungsi) yang dapat mendeskripsikan dan membedakan kelas - kelas data atau konsep-konsep, dengan tujuan dapat menggunakan model tersebut untuk memprediksi kelas dari suatu objek yang mana kelasnya belum diketahui [9]

Penelitian-penelitian yang menggunakan sinyal EEG telah banyak dilakukan untuk mengklasifikasikan emosi manusia. Metode yang digunakan pada penelitian ini menggunakan metode Convolutional Neural Network (CNN). Deep Neural Network (DNN) dan Bi-LSTM. Buku yang ditulis oleh Saputra dan Kristiyanti di tahun 2010 menjelaskan Convolutional Neural Networks merupakan algoritma yang berasal dari turunan neural network yang dapat digunakan untuk memproses data citra digital. Cara kerja algoritma CNN dalam memproses apa yang dilihat menyerupai cara kerja manusia, dimana pada manusia terdapat mata yang berfungsi sebagai alat input dan selanjutnya diproses oleh otak yang memiliki miliaran neuron, dalam CNN bagian ini disebut sebagai layer konvolusional, sehingga akan menghasilkan keluaran berupa prediksi terhadap suatu objek [10]. Penelitian menggunakan berbagai metode seperti penggunaan metode Convolutional Neural Network (CNN) telah dilakukan oleh Donmez dan Ozkurt pada tahun 2019 dimana CNN dapat mengklasifikasikan emosi dengan akurasi sebesar 84,65% [1]. Hasil penelitian Islam dkk pada tahun 2021 menunjukkan bahwa CNN adalah cara yang cukup berguna dalam klasifikasi emosi berbasis EEG [12]. Hasil penelitian Maheswari dkk pada tahun 2021 menunjukkan bahwa hasil klasifikasi yang dihasilkan mampu mencapai akurasi sebesar 98% dalam mengklasifikasikan akurasi emosi manusia [11]. Sedangkan penelitian yang dilakukan oleh Islam dkk pada tahun 2021 menghasilkan akurasi sebesar 78,22% dalam mengklasifikasikan emosi yang dihasilkan melalui data EEG [12]. Penelitian yang dilakukan oleh Wu dkk pada tahun 2020 menunjukkan bahwa klasifikasi menggunakan metode CNN lebih baik daripada menggunakan metode SVM [13]. Dan Hasil penelitian Arjun dkk pada tahun 2022 menunjukkan bahwa CNN mampu mengklasifikasikan emosi dengan baik [14].

Sun dkk pada penelitiannya pada tahun 2019 menjelaskan DNN adalah algoritma berbasis jaringan saraf yang dapat digunakan untuk pengambilan keputusan yang memiliki lebih dari satu lapisan saraf tersembunyi. Algoritma ini adalah pengembangan kecerdasan yaitu algoritma JST (Jaringan Syaraf Tiruan). Untuk mencapai akurasi tinggi dalam algoritma ini, jumlah data perlu dilatih terlebih dahulu. DNN terdiri dari beberapa lapisan dan neuron di setiap lapisan. Kedua hal ini tidak dapat ditentukan dengan menggunakan aturan yang pasti dan berlaku secara berbeda untuk data yang berbeda [15]. Penelitian tentang klasifikasi emosi dengan menggunakan Deep Neural Network (DNN) telah diteliti oleh Huang dkk pada tahun 2017 dimana hasil penelitian menunjukkan bahwa akurasi yang dicapai sebesar 94,92% [3]. Penelitian yang dilakukan oleh Zhuang dkk pada tahun 2019 menunjukkan DNN mampu mengklasifikasikan 9 jenis emosi lebih baik dibandingkan dengan metode konvensional [7]. Penelitian Sun dkk pada tahun 2017 menunjukkan bahwa akurasi yang dicapai adalah sebesar 75,83% dan metode DNN lebih baik daripada metode SVM [15]. Penelitian yang dilakukan oleh Hizlisoy dkk pada tahun 2021 meneliti bagaimana klasifikasi berdasarkan emosi setelah mendengarkan musik, hasil penelitian menunjukkan DNN lebih baik dibandingkan dengan LSTM [16].

Jang dkk dalam penelitiannya pada tahun 2020 menjelaskan bahwa LSTM dua arah (BiLSTM) berisi dua LSTM independen, yang beroperasi di kedua arah, forward atau maju dan backward atau mundur dimana Bi-LSTM dapat menggabungkan informasi masa lalu dan masa depan sehingga dua arah maju dan mundur tersebut digunakan untuk menangkap ketergantungan dari dalam dua konteks [17]. Penelitian dengan menggunakan metode Bi-LSTM telah dilakukan diantaranya Penelitian yang dilakukan oleh Hu dkk pada tahun 2020 dimana dengan menggunakan metode Bi-LSTM didapat akurasi sebesar 92,66% [18]. Penelitian dengan menggunakan metode Bi-LSTM juga dilakukan oleh Mehmood dkk pada tahun 2023 dimana hasil penelitian ini rata-rata tingkat


keberhasilan model Bi-LSTM yang diusulkan adalah 97,78% [19]. Penelitian yang dilakukan oleh Ariza dkk pada tahun 2022 dimana dengan menggunakan metode Bi-LSTM, metode yang diusulkan mencapai skor F lebih dari 78% pada intra-subjek case sesuai dengan pianis, sedangkan biola hanya skenario mencapai lebih dari 62% dari F-score [20].

Berdasarkan penelitian tentang CNN, Bi-LSTM dan DNN didapat berbagai hasil yang menunjukkan bahwa masing-masing metode mempunyai keunggulan akurasi masing-masing. Hal tersebut mendasari peneliti untuk melakukan pengujian dan perbandingan ketiga metode tersebut dengan menggunakan dataset yang berasal dari Kaggle.com, sehingga didapat gambaran metode mana yang menghasilkan akurasi yang lebih baik.

2. METODOLOGI PENELITIAN

2.1 Tahapan Penelitian

Tahapan dalam penelitian ini menggunakan metode Convolutional Neural Network (CNN), Bidirectional Long-Short Term Memory (Bi-LSTM) dan Deep Neural Network (DNN) yang dijelaskan melalui alur proses dalam flowchart berikut ini



Gambar 1. Flowchart Alur Penelitian

Tahapan-Tahapan yang dilakukan dalam penelitian adalah sebagai berikut

1. Data Set Penelitian adalah data sinyal EEG yang berasal dari kaggle.com
2. Pra-Proses Data dilakukan untuk label encoding yang digunakan untuk mengkonversi variabel kelas yang awalnya dalam bentuk data string menjadi nilai numerik. Terdapat tiga kelas yang semula dalam bentuk string, yaitu “Neutral” diubah menjadi kelas 0, “Positif” diubah menjadi kelas 1 dan “Negatif” diubah menjadi kelas 2
3. Proses membagi sebuah kumpulan data menjadi dua atau lebih subset yang berbeda dengan tujuan untuk pemisahan data menjadi dua kategori utama, yang akan digunakan dalam data training dan data testing
4. Data Training merupakan data subset yang digunakan untuk melatih model pembelajaran mesin. Model yang menggunakan data pelatihan ini untuk belajar pola dan hubungan dalam data agar dapat membuat prediksi atau pengklasifikasian yang akurat di masa depan.
5. Data testing merupakan subset data yang digunakan untuk menguji kinerja model setelah dilatih. Data Pengujian digunakan untuk mengukur sejauh mana model dapat memprediksi atau mengklasifikasikan data yang tidak pernah dilihat sebelumnya
6. Klasifikasi Model dengan menggunakan metode CNN, Bi-LSTM dan DNN dan Evaluasi Model menggunakan Confusion Matrix

2.2 Confusion Matrix

Confusion Matrix adalah alat visualisasi yang biasa digunakan pada supervised learning. Tiap kolom pada matriks adalah contoh kelas prediksi, sedangkan tiap baris mewakili kejadian di kelas yang sebenarnya. Dalam penelitian ini, digunakan Confusion Matrix multikelas dengan 3 kelas. Proses perhitungan akurasi, presisi, recall, dan F1-score melibatkan penghitungan TP_i, TN_i, FP_i, dan FN_i untuk setiap kelas. Penempatan TP_i, TN_i, FP_i, dan FN_i dalam Confusion Matrix dilakukan secara khusus untuk Kelas 0 dalam Tabel 1, Kelas 1 dalam Tabel 2, dan Kelas 2 dalam Tabel 3.

Table 1. Confusion matrix kelas 0

Label 0	Actual		
	0	1	2
Prediction 0	TP _i	FP _i	FP _i
Prediction 1	FN _i	TN _i	
Prediction 2	FN _i		TN _i

Tabel 2. Confusion matrix kelas 1

Label 1	Actual		
	0	1	2
Prediction 0	TN _i	FN _i	

Label 1	Actual		
	0	1	2
1	FP _i	TP _i	FP _i
2		FN _i	TN _i

Tabel 3. Confusion matrix kelas 2

Label 2	Actual		
	0	1	2
0	TN _i		FN _i
Prediction 1		TN _i	FN _i
2	FP _i	FP _i	TP _i

Langkah - langkah evaluasi dasar dari confusion matrix menghasilkan persamaan - persamaan berikut :

$$Accuracy = \frac{\sum_{i=1}^l \frac{TP_i + TN_i}{TP_i + FN_i + TN_i + FP_i}}{l} * 100\% \tag{1}$$

$$Precision = \frac{\sum_{i=1}^l TP_i}{\sum_{i=1}^l (FP_i + TP_i)} * 100\% \tag{2}$$

$$Recall = \frac{\sum_{i=1}^l TP_i}{\sum_{i=1}^l (TP_i + FN_i)} * 100\% \tag{3}$$

$$F1\ score = \frac{2 * Presisi * Recall}{Presisi + Recall} \tag{4}$$

3. HASIL DAN PEMBAHASAN

3.1 Pengumpulan Data

Data direkam dari dua partisipan yang terdiri dari satu laki-laki dan satu perempuan untuk menentukan kondisi netral, positif, dan negatif. Pengumpulan data ini dilakukan sesuai dengan panduan Bird dkk pada tahun 2019 yaitu melalui penggunaan headband Muse EEG yang dilengkapi dengan elektroda kering, yang memungkinkan untuk merekam aktivitas EEG pada titik lokasi TP9, AF7, AF8, dan TP10 [21]. Data yang digunakan dalam penelitian ini adalah data sinyal ElectroEncephaloGram (EEG) yang berasal dari laman kaggle.com dengan rincian sebagai berikut

Tabel 4. Data Penelitian

Data label	Number of data
Positive	708
Negative	708
Neutral	716
Total	2132

Berdasarkan data yang berasal dari laman kaggle.com yang terdapat pada tabel 4 didapat sinyal EEG positif sebanyak 708 data, data sinyal negatif sebanyak 708 data dan sinyal netral sebanyak 716 data

3.2 Pra-Proses Data

Berikut merupakan proses Label Encoding pada data yang digunakan dalam penelitian

```
# Mapping for labels
label_mapping = {'NEUTRAL': 0, 'POSITIVE': 1, 'NEGATIVE': 2}

# Added a new label column with numeric values based on the mapping
dataframe['numeric_label'] = dataframe['label'].map(label_mapping)

# Import LabelEncoder from sklearn.preprocessing
from sklearn.preprocessing import LabelEncoder

# Initialize LabelEncoder
model_label_encoding = LabelEncoder()

# Do a label transformation to a numeric value
dataframe['label'] = model_label_encoding.fit_transform(dataframe['label'])
```

Gambar 2. Label Encoding

Pada proses ini, data-data penelitian yang sebelumnya dalam bentuk string diubah menjadi data numeric, dimana data neutral menjadi 0, data positif menjadi 1 dan negatif menjadi 2.


3.3 Split Data

Pada tahapan split data, dilakukan tiga kali validasi dengan nilai learning rate sebesar 0,001, epoch 10 dan batch size 128. Adapun perbandingan jumlah data training dan data testing pada percobaan yang dilakukan adalah sebagai berikut

1. Validasi pertama : Data latih 90% dan data uji 10%
2. Validasi kedua : Data latih 80% dan data uji 20%
3. Validasi ketiga : Data latih 70% dan data uji 30%


3.4 Klasifikasi dan Evaluasi Model

3.4.1 Hasil Validasi Metode CNN, Bi-LSTM dan DNN dengan Data Latih 90% dan Data Uji 10%



Gambar 3. Grafik Fungsi Val_loss CNN, Bi-LSTM dan DNN

Grafik fungsi val_loss pada Gambar 3 menunjukkan proses pelatihan pada model telah baik karena loss yang dihasilkan mengalami penurunan.



Gambar 4. Grafik Fungsi val_accuracy CNN, Bi-LSTM dan DNN

Grafik val_accuracy pada Gambar 4 juga menunjukkan hasil akurasi yang diperoleh model lebih baik karena mengalami kenaikan.

```

7/7 [=====] - 0s 15ms/step

```

	precision	recall	f1-score	support
0	0.99	1.00	0.99	82
1	0.96	0.94	0.95	69
2	0.95	0.95	0.95	63
accuracy			0.97	214
macro avg	0.97	0.96	0.97	214
weighted avg	0.97	0.97	0.97	214

Gambar 5. Hasil Evaluasi Kinerja CNN

Confusion matrix dari validasi pertama dapat dilihat Pada Gambar 5, hasil akurasi dari model CNN memiliki nilai precision 97%, recall 96%, dan f1-score 97%, accuracy 97%.

```

7/7 [=====] - 2s 88ms/step
              precision    recall  f1-score   support

     0         1.00      1.00      1.00         82
     1         0.99      1.00      0.99         69
     2         1.00      0.98      0.99         63

 accuracy              1.00         214
 macro avg           1.00      0.99      0.99         214
 weighted avg       1.00      1.00      1.00         214
    
```

Gambar 6. Hasil Evaluasi Kinerja Bi-LSTM

Confusion matrix dari validasi pertama dapat dilihat Pada Gambar 6 hasil akurasi dari model Bi-LSTM memiliki nilai precision 100%, recall 99%, dan f1-score 99%, accuracy 100%.

```

7/7 [=====] - 0s 11ms/step
              precision    recall  f1-score   support


     0         0.96      0.99      0.98         82
     1         0.94      0.90      0.92         69
     2         0.94      0.95      0.94         63

 accuracy              0.95         214
 macro avg           0.95      0.95      0.95         214
 weighted avg       0.95      0.95      0.95         214
    
```

Gambar 7. Hasil Evaluasi Kinerja DNN.

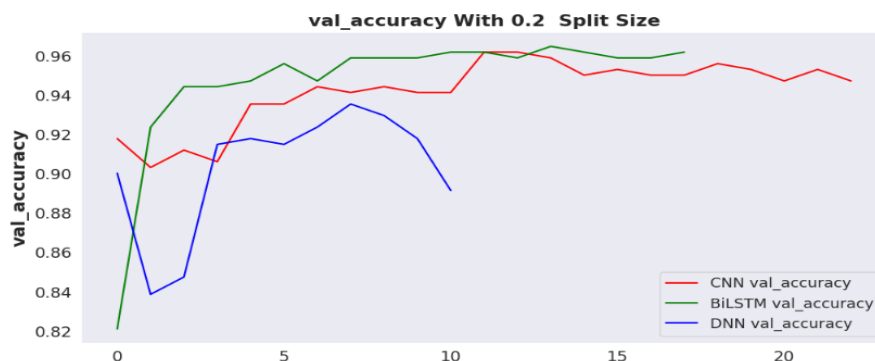
Confusion matrix dari validasi pertama dapat dilihat Pada Gambar 7 untuk model model CNN memiliki nilai precision 95%, recall 95%, dan f1-score 95%, accuracy 95%.

3.4.2 Hasil Validasi Metode CNN, Bi-LSTM dan DNN dengan Data Latih 80% dan Data Uji 20%



Gambar 8. Grafik Fungsi Val_loss CNN, Bi-LSTM dan DNN

Grafik fungsi val_loss pada Gambar 8, menunjukkan proses pelatihan pada model telah baik karena loss yang dihasilkan mengalami penurunan.



Gambar 9. Grafik Fungsi val_accuracy CNN, Bi-LSTM dan DNN

Grafik val_accuracy pada Gambar 9, juga menunjukkan hasil akurasi yang diperoleh model lebih baik karena mengalami kenaikan.

```

14/14 [=====] - 0s 8ms/step
      precision    recall  f1-score   support

     0       0.99      0.99      0.99       164
     1       0.95      0.96      0.95       148
     2       0.96      0.95      0.95       115

 accuracy                0.97       427
 macro avg       0.97      0.97      0.97       427
 weighted avg    0.97      0.97      0.97       427
  
```

Gambar 10. Hasil Evaluasi Kinerja CNN

Confusion matrix dari validasi pertama dapat dilihat Pada Gambar 10, hasil akurasi dari model CNN memiliki nilai precision 97%, recall 96%, dan f1-score 97%, accuracy 97%.

```

14/14 [=====] - 3s 86ms/step
      precision    recall  f1-score   support

     0       0.99      0.99      0.99       164
     1       0.98      0.97      0.98       148
     2       0.97      0.98      0.98       115

 accuracy                0.98       427
 macro avg       0.98      0.98      0.98       427
 weighted avg    0.98      0.98      0.98       427
  
```

Gambar 11. Hasil Evaluasi Kinerja Bi-LSTM

Confusion matrix dari validasi pertama dapat dilihat Gambar 11 hasil akurasi dari model Bi-LSTM memiliki nilai precision 98%, recall 98%, dan f1-score 98%, accuracy 98%.

```

14/14 [=====] - 0s 8ms/step
      precision    recall  f1-score   support

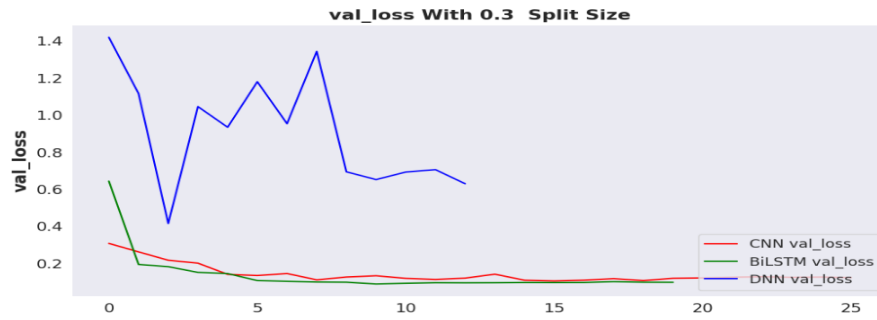
     0       0.96      0.98      0.97       164
     1       0.94      0.82      0.88       148
     2       0.85      0.97      0.91       115

 accuracy                0.92       427
 macro avg       0.92      0.92      0.92       427
 weighted avg    0.92      0.92      0.92       427
  
```

Gambar 12. Hasil Evaluasi Kinerja DNN


Confusion matrix dari validasi pertama dapat dilihat Gambar 12 hasil akurasi dari model DNN memiliki nilai precision 92%, recall 92%, dan f1-score 92%, accuracy 92%.

3.4.3 Hasil Validasi Metode CNN, Bi-LSTM dan DNN dengan Data Latih 70% dan Data Uji 30%



Gambar 13. Grafik Fungsi Val_loss CNN, Bi-LSTM dan DNN

Grafik fungsi val_loss pada Gambar 13 menunjukkan proses pelatihan pada model telah baik karena loss yang dihasilkan mengalami penurunan.



Gambar 14. Grafik Fungsi val_accuracy CNN, Bi-LSTM dan DNN

Grafik val_accuracy pada Gambar 14, juga menunjukkan hasil akurasi yang diperoleh model lebih baik karena mengalami kenaikan.

```

20/20 [=====] - 4s 86ms/step
      precision    recall  f1-score   support

      0         1.00      0.99      1.00       231
      1         0.96      0.97      0.96       219
      2         0.96      0.96      0.96       190

 accuracy                   0.97       640
 macro avg                 0.97      0.97       640
 weighted avg              0.98      0.97      0.98       640
    
```

Gambar 15. Hasil Evaluasi Kinerja CNN

Confusion matrix dari validasi ketiga dapat dilihat Pada Gambar 15 hasil akurasi dari model CNN memiliki nilai precision 96%, recall 96%, dan f1-score 96%, accuracy 96%.

```

20/20 [=====] - 4s 86ms/step
      precision    recall  f1-score   support

      0         1.00      0.99      1.00       231
      1         0.96      0.97      0.96       219
      2         0.96      0.96      0.96       190

 accuracy                   0.97       640
 macro avg                 0.97      0.97       640
 weighted avg              0.98      0.97      0.98       640
    
```

Gambar 16. Hasil Evaluasi Kinerja Bi-LSTM

Confusion matrix dari validasi pertama dapat dilihat Gambar 16 hasil akurasi dari model Bi-LSTM memiliki nilai precision 94%, recall 94%, dan f1-score 94%, accuracy 94%.

```

20/20 [=====] - 0s 7ms/step

```

	precision	recall	f1-score	support
0	0.96	0.97	0.97	231
1	0.92	0.85	0.89	219
2	0.89	0.95	0.92	190
accuracy			0.93	640
macro avg	0.92	0.93	0.92	640
weighted avg	0.93	0.93	0.92	640

Gambar 17. Hasil Evaluasi Kinerja DNN

Confusion matrix dari validasi pertama dapat dilihat Pada Gambar 17 hasil akurasi dari model DNN memiliki nilai precision 92%, recall 92%, dan f1-score 92%, accuracy 92%.

4. KESIMPULAN

Berdasarkan hasil dan percobaan yang dilakukan dalam penelitian ini, dapat disimpulkan bahwa ketiga model, yaitu CNN, Bi-LSTM dan DNN, telah berhasil diimplementasikan untuk tujuan pengenalan emosi berdasarkan data EEG. Meskipun ketiga model tersebut memiliki performa yang relatif baik dalam melakukan klasifikasi emosi, terdapat variasi dalam hasil kinerja keduanya. Dalam validasi yang melibatkan berbagai pembagian data latih dan uji, terlihat bahwa model Bi-LSTM secara konsisten mencapai akurasi yang lebih tinggi dibandingkan dengan model CNN dan DNN. Hal ini menunjukkan bahwa dalam konteks dataset ini, Bi-LSTM lebih baik dalam memahami dan memodelkan pola-pola yang terkait dengan emosi manusia berdasarkan data EEG. Pada beberapa skenario validasi, akurasi CNN dan DNN juga mencapai tingkat yang baik, namun masih sedikit di bawah performa Bi-LSTM. Selain itu, evaluasi melalui confusion matrix juga memberikan wawasan yang lebih mendalam tentang kinerja ketiga model. Hasil presisi, recall, dan F1-score dari kedua model ini menunjukkan bahwa keduanya memiliki kemampuan yang sebanding dalam mengenali berbagai kelas emosi. Namun, penting untuk dicatat bahwa performa model dapat dipengaruhi oleh berbagai faktor seperti pembagian data latih dan uji, arsitektur model, dan parameter yang digunakan. Oleh karena itu, pemilihan model yang tepat perlu mempertimbangkan faktor-faktor tersebut dan memerlukan analisis lebih lanjut untuk memastikan hasil yang paling optimal dalam berbagai situasi. Secara keseluruhan, penelitian ini memberikan gambaran komparatif antara model CNN, Bi-LSTM dan DNN dalam tugas pengenalan emosi berdasarkan data EEG. Hasil ini dapat membantu dalam memilih model yang sesuai untuk aplikasi praktis dalam pengenalan emosi manusia menggunakan data EEG..

REFERENCES

- [1] H. Donmez and N. Ozkurt, "Emotion Classification from EEG Signals in Convolutional Neural Networks," Proc. - 2019 Innov. Intell. Syst. Appl. Conf. ASYU 2019, 2019, doi: 10.1109/ASYU48272.2019.8946364.
- [2] H. Mei and X. Xu, "EEG-based emotion classification using convolutional neural network," in 2017 International Conference on Security, Pattern Analysis, and Cybernetics, SPAC 2017, Dec. 2018, vol. 2018-Janua, pp. 130–135, doi: 10.1109/SPAC.2017.8304263.
- [3] J. Huang, X. Xu, and T. Zhang, "Emotion classification using deep neural networks and emotional patches," Proc. - 2017 IEEE Int. Conf. Bioinforma. Biomed. BIBM 2017, vol. 2017-Janua, pp. 958–962, 2017, doi: 10.1109/BIBM.2017.8217786.
- [4] H. Zhang, "Expression-eeG based collaborative multimodal emotion recognition using deep autoencoder," IEEE Access, vol. 8, pp. 164130–164143, 2020, doi: 10.1109/ACCESS.2020.3021994.
- [5] B. Yang, X. Han, and J. Tang, "Three class emotions recognition based on deep learning using staked autoencoder," Proc. - 2017 10th Int. Congr. Image Signal Process. Biomed. Eng. Informatics, CISP-BMEI 2017, vol. 2018-Janua, pp. 1–5, 2018, doi: 10.1109/CISP-BMEI.2017.8302098.
- [6] J. J. Lasiman and D. P. Lestari, "Speech Emotion Recognition for Indonesian Language Using Long Short-Term Memory," 2018 Int. Conf. Comput. Control. Informatics its Appl. Recent Challenges Mach. Learn. Comput. Appl. IC3INA 2018 - Proceeding, pp. 40–43, 2019, doi: 10.1109/IC3INA.2018.8629525.
- [7] J. R. Zhuang, Y. J. Guan, H. Nagayoshi, K. Muramatsu, K. Watanuki, and E. Tanaka, "Real-time emotion recognition system with multiple physiological signals," J. Adv. Mech. Des. Syst. Manuf., vol. 13, no. 4, pp. 1–16, 2019, doi:

- 10.1299/jamdsm.2019jamdsm0075.
- [8] K. Nalbant, B. M. Kalaycı, D. Akdemir, S. Akgül, and N. Kanbur, “Emotion regulation, emotion recognition, and empathy in adolescents with anorexia nervosa,” *Eat. Weight Disord.*, vol. 24, no. 5, pp. 825–834, 2019, doi: 10.1007/s40519-019-00768-8.
- [9] L. N. Rani, “Klasifikasi Nasabah Menggunakan Algoritma C4 . 5 Sebagai Dasar Pemberian Kredit,” 2016.
- [10] I. Saputra and D. A. Kristiyanti, “Machine learning untuk pemula,” in *Penerbit INFORMATIKA*, Penerbit INFORMATIKA, 2022.
- [11] D. Maheshwari, S. K. Ghosh, R. K. Tripathy, M. Sharma, and U. R. Acharya, “Automated accurate emotion recognition system using rhythm-specific deep convolutional neural network technique with multi-channel EEG signals,” *Comput. Biol. Med.*, vol. 134, no. April, p. 104428, 2021, doi: 10.1016/j.combiomed.2021.104428.
- [12] M. R. Islam et al., “EEG Channel Correlation Based Model for Emotion Recognition,” *Comput. Biol. Med.*, vol. 136, no. August, p. 104757, 2021, doi: 10.1016/j.combiomed.2021.104757.
- [13] P. Wu, X. Li, S. Shen, and D. He, “Social media opinion summarization using emotion cognition and convolutional neural networks,” *Int. J. Inf. Manage.*, vol. 51, no. December 2018, p. 101978, 2020, doi: 10.1016/j.ijinfomgt.2019.07.004.
- [14] Arjun, A. S. Rajpoot, and M. R. Panicker, “Subject independent emotion recognition using EEG signals employing attention driven neural networks,” *Biomed. Signal Process. Control*, vol. 75, no. February, p. 103547, 2022, doi: 10.1016/j.bspc.2022.103547.
- [15] L. Sun, B. Zou, S. Fu, J. Chen, and F. Wang, “Speech emotion recognition based on DNN-decision tree SVM model,” *Speech Commun.*, vol. 115, no. October, pp. 29–37, 2019, doi: 10.1016/j.specom.2019.10.004.
- [16] S. Hizlisoy, S. Yildirim, and Z. Tufekci, “Music emotion recognition using convolutional long short term memory deep neural networks,” *Eng. Sci. Technol. an Int. J.*, vol. 24, no. 3, pp. 760–767, 2021, doi: 10.1016/j.jestch.2020.10.009.
- [17] B. Jang, M. Kim, G. Harerimana, S. U. Kang, and J. W. Kim, “Bi-LSTM model to increase accuracy in text classification: Combining word2vec CNN and attention mechanism,” *Appl. Sci.*, vol. 10, no. 17, 2020, doi: 10.3390/app10175841.
- [18] X. Hu, S. Yuan, F. Xu, Y. Leng, K. Yuan, and Q. Yuan, “Scalp EEG classification using deep Bi-LSTM network for seizure detection,” *Comput. Biol. Med.*, vol. 124, no. June, p. 103919, 2020, doi: 10.1016/j.combiomed.2020.103919.
- [19] I. Mehmood et al., “Deep learning-based construction equipment operators’ mental fatigue classification using wearable EEG sensor data,” *Adv. Eng. Informatics*, vol. 56, no. April, p. 101978, 2023, doi: 10.1016/j.aei.2023.101978.
- [20] I. Ariza, L. J. Tardón, A. M. Barbancho, I. De-Torres, and I. Barbancho, “Bi-LSTM neural network for EEG-based error detection in musicians’ performance,” *Biomed. Signal Process. Control*, vol. 78, no. May, p. 103885, 2022, doi: 10.1016/j.bspc.2022.103885.
- [21] J. J. Bird, A. Ekart, and D. R. Faria, “Mental Emotional Sentiment Classification with an EEG-based Brain-machine Interface HANDLE Project (EU FP7) View project EMG-controlled 3D Printed Prosthetic Hand for Academia View project,” no. January, 2019, [Online]. Available: <http://dx.doi.org/10.17501>